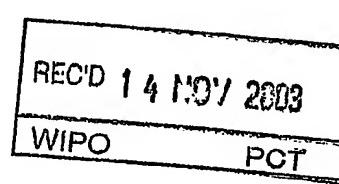


Helsinki 17.10.2003

E T U O I K E U S T O D I S T U S  
P R I O R I T Y D O C U M E N THakija  
ApplicantHoneywell Oy  
JyväskyläPatentihakemus nro  
Patent application no

20021578

Tekemispäivä  
Filing date

03.09.2002

Kansainvälinen luokka  
International class

G06T

Keksinnön nimitys  
Title of invention

"Paperin karakterisointi"

Tätten todistetaan, että oheiset asiakirjat ovat tarkkoja jäljennöksiä Patentti- ja rekisterihallitukselle alkuaan annetuista selityksestä, patenttivaatimuksista, tiivistelmästä ja piirustuksista.

This is to certify that the annexed documents are true copies of the description, claims, abstract and drawings originally filed with the Finnish Patent Office.

*Markku Tehikoski*  
Markku Tehikoski  
Apulaistarkastaja

**PRIORITY DOCUMENT**  
SUBMITTED OR TRANSMITTED IN  
COMPLIANCE WITH  
RULE 17.1(a) OR (b)

Maksu 50.€  
Fee 50 EUR

*Maksu perustuu kauppa- ja teollisuusministeriön antamaan asetukseen 1027/2001 Patentti- ja rekisterihallituksen maksullisista suoritteista muutoksineen.*

*The fee is based on the Decree with amendments of the Ministry of Trade and Industry No. 1027/2001 concerning the chargeable services of the National Board of Patents and Registration of Finland.*

## Paperin karakterisointi

Keksintö liittyy paperin laadun karakterisointiin ja luokitukseen käytämisällä konenäköä tai muuta kaksiulotteisesti kuvaavaa menetelmää.

5

Hakemuksen liitteenä on kirjallisuusluettelo, johon viitataan hakasulkuihin merkityillä viitenumeroilla. Tunnuttuun tekniikkaan viitataan viitejulkaisujen muodossa aina kunkin asian yhteydessä.

- 10 Keksinnön tarkoituksena on saada aikaan paperin laadun karakterisointimenetelmä, joka antaa nykyisiä menetelmiä luotettavamman luokituksen ilman ihmillisistä tekijöistä johtuvaa vaihtelua.

- Tunnuttua tekniikkaa edustavat konenäköön perustuvat paperin laadutusjärjestelmät ovat aikaisemmin pohjautuneet ohjattuihin oppimismenetelmiin sekä vanhoihin ja tehottomiin kuvista laskettaviin piirteisiin. Piirteinä on yleensä käytetty yhteisesiintymämatriiseista saatavia mittoja, tehospektrianalyysia sekä specific perimeter -piirrettä. Myös kuvien harmaasävyjen keskiarvon ja varianssin on oletettu kuvaavan paperin neliömassan vaihteluita. Piirteistä on muodosteltu numeerinen mitta, joka kuvaaa paperin laatuja. Tämän numeerisen mitan perusteella on sitten luokiteltu paperin formaatiota rai muuta ominaisuuksia. [1, 2, 3, 4, 5]

- Vanhat tekstuuriplirteet eivär kykene antamaan paperin tekstuurista kovinkaan tarkkaa tietoa ja ne ovat herkkiä olosuhteiden, kuten valaistuksen, muutoksille. Kun heikosti diskriminoivat plirteet yhdistetään ohjattuun luokittelijan opettamiseen, heikkenee järjestelmän karakterisointikyky entisestään. Tämä johtuu siitä, että perinteiset ohjaukset menetelmät ovat erittäin herkkilä ihmisen tekemille virheille. Tämiset tekevät yleensä virheitä opetusnäytteiden valinnassa ja niiden nimeämässä. Lisäksi ihmisten tekemät valinnat ovat subjektiivisia ja siten eri ihmisten tulkinnot eroavat toisistaan. Laaduntarkas-

tuksen kannalta tämä ei ole toivottavaa. Ohjattuhiin oppimismenetelmiin pohjautuvan järjestelmän uudelleenopetus on vaikeaa jos olosuhteiden muutokset tätä vaativat. Usein nain on, sillä kehittymättömät tekstuuriplirileel ovat erittäin herkkiä olosuhteissa tapahtuville muutoksille.

5

- Ongelmana on ollut se, että paperia on analysoitu heikosti diskriminoivilla tekstuuriplirileillä. Lisäksi jo ennestään pistoutuneesta ja ei-normaalijakäytuneesta piiriavaruudesta on pyritty selvittämään luokkarajoja parametrisilla menetelmillä. Luokittelijoita operettaessa ja luokkarajojen etsimisessä on käytetty ohjattuja menetelmiä, mikä lisää virheiden määrää.

- Paperin karakterisoinnissa pyritään laittelemaan keskenään ominaisuuksiltaan samanlaiset paperit samaan kategoriaan. Paperia voidaan kuvata koko sen valmistuksen ajan, näin saadaan tietoa myös siltä, mitkä olivat hyvän tai huonon paperin ominaisuudet valmistusprosessin eri valheissa. Ilman karakterisointia ei pelkkien kuvien perusteella pystytä hakemaan prosessista hyödyllistä informaatiota, koska kuvien arviointi ja luokittelut on ihmisenelle hyvin vaikeaa ja subjektiivista, lisäksi suuren datamäään käsitteily on mahdotonta ilman automaattista, numeroarvoihin tai symboliin perustuvaa luokitusta.
- Karakterisoinnin avulla saadaan paperin laatu luokiteltua useisiin luokkiin, joiden perusteella pystytään jäljittämään tuotantoprosessin toimintaa ja yrittää parantaa haluttuja ominaisuuksia paperissa, kunhan tiedetään milkä tekijät vaikuttavat paperin laatuun, ja millalista paperi on ollut missäkin tuotannon valheessa. Itse karakterisolinnin ei tarvitse ottaa kantaa paperin hyvyyteen, riittää kunhan samanlaiset paperit saa saman luokan. Luokitukseen muukaan voidaan ohjata prosessia tai lajitella paperia laatuluokkiin.

- Konenäkömenetelmissä paperikuvista pyritään laskemaan juukko plirteitä, jotka kuvaaval paperin ominaisuuksia mahdollisimman tarkasti [1, 2, 3, 4, 5].
- Tyypillisistä ominaisuuksista ovat esimerkiksi paperin painettavuus ja vetolujuus. Laskettaval plirleel oval numeerisia mittoja ja ne muodostavat moniulottei-

seen pürreavaruuteen pirstoutuneita klustereita. Pürreavaruus voi olla erittäin moniulotteinen, ja on selvää, että eri paperilaatuja kuvaavat pürteet on vaikea löytää pirstoutuneesta avaruudesta. Kuvassa 1 on esimerkki pürreavaruudesta, joka esitetään yksin-kertaisuuden vuoksi kaksiulotteisessa koordinaatistossa. Kuvassa olevat rastit kuvaavat pürteiden arvoja, ja kuyaan vedetty viiva mahdollista paperin painettavuusominaisuuksien muuttumista.

Selityksessä viitataan seuraaviin kuviin:

10 Kuvassa 1 on esitetty pürteiden pirstoutuminen ja ominaisuuksien raja.

Kuvassa 2 on esitetty moniulotteisen pürredatan klusteroltoimisen kaksiulottaiseen koordinaatistoon.

15 Kuvassa 3 on keksinnön mukaisen luokittelun periaatekaavio

Kuvassa 4 on esitetty 3x3 -kokoinen LRP-pürteen laskeminen.

Kuvassa 5 on esitetty pisteen ympyrän kehällä oleva naapurusto, josta LPB-  
20 pürre lasketaan.

Kuvassa 6 on esitetty SOM:n käyttö luokittelijana

Kuvassa 7 on kaavikuvaa tuotannon alkana suoritettavasta paperin karakte-  
risoinnista.

Perinteiset parametrikset menetelmät elvät kykenne lüylämään tarkasti eri paperilaatujen rajoja, sillä ne tekevät oletuksia dataan jakautumisesta. Kek-  
sinnön mukaisessa menetelmässä datalle tehdään aluksi kuvaus kaksiulottei-  
seen koordinaatistoon. Jokaiselle klusterille annetaan leima sen perusteella,  
30 minkä laajuista paperia klusteri edustaa. Eli paperin laadusta voidaan tehdä

- päätelmiä sen perusteella minne näyte kaksilottelissa koordinaatistossa sijoittuu. Kuvassa 2 on esimerkki moniulotteisen piirreavaruuden kuvaamisesta kaksilotteiseen koordinaatistoon menetelmällä, joka säälyttää datan paikallisen rakenteen ja näytteiden väliset keskinäiset eläisyysdet [6, 7, 8, 9, 10].
- 5 Leimat 3a – 3d kuvaavat paperin eri ominaisuuksia, samalla leimalla merkitylle alueelle luokiteltu paperi on kyseisen ominaisuuden suhteenvaihtoista muiden saman luokan paperien kanssa. Leimat annetaan jälkkätähden, ja esimerkiksi vetolujuudelle, kiihtyvyydelle tai painettavuudelle tulee yleensä eri aluejako ja luonnollisesti eri leimat.
- 10 Menetelmässä data järjestäytyy automaattisesti siten, että näytteiden keskinäiset sijainnit uudessa koordinaatistossa ovat samat kuin alkuperäisessä moniulotteisessa piirreavaruudessa. Paperilaaduista voidaan tehdä luotettavia päätelmiä sen perusteella minne se uudessa koordinaatistossa sijoittuu. Daten jakautumista ei tehdä aluksi minkäänlaisia oletuksia ja se voi olla minkälaisia tahansa. Erilaisen tekstuurin omaavat paperit volvat silti omata sarttialaiset paino-ominaisuudet. Tämä voidaan huomioida leimattaessa eri klustereita. Tehokkailla tekstuuripliirteillä, kuten LBP:illä, paperin pintakuviointia voidaan analysoida erittäin tehokkaasti [11, 12].
- 15 20 Nyr esirettävässä keksinnössä yhdistetään ohjaamaton oppimismenetelmä, tehokkaat harmaasävyinvariantit tekstuuripliirteet sekä moniulotteisen piirreavaruuden havainnollinen visualisointi piirreavaruuden ulottuvuuksia vähentämällä. Menetelmässä ihmisen ei tarvitse oletuksia ja päätelmiä opetusmateriaalista, vaan opetusdata järjestäytyy automaattisesti ominaisuuksensa mukaan. Moniulotteinen piirreavaruus kuvautuu havainnolliseen muodoon ja näytteiden sijaintia piirreavaruudessa voidaan visualisoida.
- 25 Uudet kehittyneet tekstuurimenetelmät antavat tarkkaa tietoa tekstuurin mikro-rakenneesta. Tällaisia harmaasävyinvariantteja tekstuuripliirteitä ovat esimerkiksi paikallisia binäärikuvioita mittaavat LBP-piirteet ja sen muunnokset

[11, 12]. Tutkittaessa paperin pintaa näillä piirteillä, saadaan selvitettyä tärkeitä ominaisuuksia paperista. Yhdistelemällä tehokkaat tekstuuripiirteet ohjaamattomaan oppimismenetelmään voidaan laadutustarkkuutta parannettua huomattavasti.

5

Menetelmän kaaviokuva on esitetty kuvassa 3. Opetusjoukosta 11 lasketaan aluksi tekstuuripiirteitä vaiheessa 12, joita käytetään luokittelijan 13 opettamiseen. Moniulotteisen piirre-avaruuden ulottuvuuksia vähennetään, jotta sitä voidaan visualisoida havainnollisesti. Luokittelut suoritetaan myös käytäen uutta piirreavaruummaa 14. Ihmisen tehtäväksi jäät siis nimetä ja valita luokittelut alueet vaiheet ja saattaa ne helpommin ymmärrettävään muotoon tai saattaa paperilaadut hyvysjärjestykseen niin, että niiden mukaan voidaan myöhemmin säättää prosessia. Ihmisen tehtävä nä on myös valita opetusjouko niin, että saadaan edustava otos erilaisista paperista. Näitä tehtäviä on ku-  
10 vattu viitenumeroilla 15,16,17 ja 18.

Menetelmässä paperin ominaisuudet kuvataan ensin tehokkalla tekstuuri-  
piirteillä, mikä vähentää huomattavasti piirreavaruden pirstoutumista. Mu-  
uliotteinen piirre-avaruus kuvataan vähempiulotteliseen koordinaatistoon si-  
20 ten, että datan palkallinen rakenne säilyy. Vähempiulotteisessa koordinaatis-  
tossa olevat klusterit edustavat eri laatuisia papereita. Eri klusterit riippuvat  
sen mukaan mitä paperilaatua kyseinen klusteri edustaa. Tämän jälkeen uu-  
teen koordinaatistoon voidaan luokittella eri laatuisia papereita etsimällä klu-  
steri, johon tarkasteltava paperi klusteroituu. Klusterointiin piirreavaruden  
25 kaaviokuva on esitettty kuvassa 2.

Piirleel voidaan irrollaa esimerkiksi käyttämällä paikallislin binaarikuvioihin perustuvia tekstuurimittuja. LBP (Local Binary Pattern) -piirteet kuvataso-  
paikallisessa ympäristössä esiintyvää kuviointia [11, 12]. Alkuperäinen LBP-  
30 piirre [11] on esimerkiksi 3x3-ympäristöstä laskettava tekstuuripiirre, jonka laskemista on havainnollistettu kuvassa 4. Kuvan esimerkissä 3x3-ympäristö

- 31 kynnystetään (nuoli 11) ympäristön keskipisteen (CV) harmaasävin mu-  
kaan kaksitasonseksi 32: kynnystysarvoa CV suuremmat tai sen kanssa sa-  
mansuuruiset pikselit saavat arvon 1, ja pienemmät kynnystyvat 0:ksi. Kyn-  
nystämisen jälkeen saadut arvot 32 kerrotaan (nuoli 42) LBP-operaattorilla  
 5 33, jolloin saadaan tulomatriisi 34, jonka alkiot lasketaan yhteen (nuoli 44),  
jolloin saadaan muodostettua LBP:n arvo. Toinen tapa ajatella LBP:n laske-  
minen on muodostaa 8-bittinen koodisana suoraan kynnystehystä ympäristös-  
tä. Esimerkin tapauksessa koodisana olisi  $10010101_2$ , joka on kymmenkanta-  
järjestelmässä 149.
- 10 LBP-piirteistä on myös muodostettu erilaisia moniresoluutio- ja kiertoinva-  
rianttimalleja [12]. Lisäksi erilaisten binäärikuvioiden vaikutusta LBP-  
operaattorin suorituskykyyn on tutkittu, jolloin on mahdollistettu tiettyjen  
kuvioiden poisjättämisen piirrejakaumaa muodostettaessa [12]. Nämä LBP-  
 15 piirrejakauma on saatu lyhyemmäksi.

Moniresoluutio-LBP tarkoittaa sitä, että pisteen naapurusto on valittu use-  
ammalta eri etäisyydeltä. Etäisyys voi periaatteessa olla mikä tahansa positi-  
vinen luku ja laskennassa käytettävien pisteen lukumäärä voi myös vaihdell-  
 20 la etäisyyden mukaan. Kuva 5 on esitetty pisteen naapurusto etäisyydellä  
neljä ( $d=4$ ). Pisteen ympärille on piirretty ympyrä, jonka säde on sama kuin  
valittu etäisyys. Ympyrän kehältä valitaan näytteitä kulman  $\alpha$ :n osoittamin  
vältein siten, että  $N\alpha = 2\pi$ , missä  $N$  on valittujen näytteiden lukumäärä. Jos  
ympyrän kehällä oleva näyte ei satu tarkasti jonkin pikselin kohdalle tehdään  
 25 sille interpolointi, jolla pisteen koordinaatit saatetaan vastaamaan kehällä  
olevia koordinaatteja. Tyypillisesti käytettävät etäisyydet ovat 1, 2 ja 3, sekä  
näytteiden lukumäärät vastaavasti 8, 16 ja 24. Mitä enemmän pistettä vali-  
taan, sitä suurempi saatu LBP-jakauma on. 24-ulotteinen piirreavaruuus tuot-  
taa jo yli 16 miljoonaa pylvästä sisältävän LBP-jakauman.

30

- Suurten LBP-jakaumien käyttäminen laskennassa on hankalaa. Jakauma saadaan pienemmäksi ja laskennan kannalta järkeväksi kokonaisksi huomioimalla LBP-kodeista ainoastaan tietty, ennalta valittu, osa. Valitut koodit ovat niin sanottuja jatkuvia binäärikoodeja, joissa ympyrän kehällä olevat luvut sisältävät korkeintaan kaksi hittivaihdosta 0:sta 1:een tai päinvastoin. Näin ollen valitut koodisanat sisältävät pitkiä nollien tai ykkösten muodostamia yhtenäisiä ketjuja. Kondien valinta perustuu tietoon, että tiettyllä LBP-kuvioilla voidaan ilmaista jopa yli 90 % tekstuurissa olevasta kuvioinnista. Käytämällä laskennassa ainoastaan näitä jatkuvia binääriketjuja saadaan 8 näytteen LBP-jakauma pienentää 256:sta 58:aan. 16 näytteen LBP-jakauma pienenee puolestaan reilusta 65 tuhannesta 242:een ja 24 näytteen jakauma yli 16 miljoonasta 554:ään. [12]

- Kiertoinvariantin LBP-piirteen laskemiseen otetaan mukaan ennalta valittu LBP-kuvioiden alajoukko [12]. Kuviot ovat valittu siten, että ne ovat invariantteja tekstuurissa tapahtuvalle kiertymiselle. Kiertoinvarianttien LBP-piirteiden käyttäminen ei-invariantissa ongelmassa laskee piirteen suorituskykyä. Paperin karakterisointi ei kuitenkaan ole kiertoinvariantti ongelma.
- Luokittelu ja klusterointi voidaan tehdä esimerkiksi käytännällä ilseorganisoivin karttoihin perustuvaa teknikkaa [13]. Ilseorganisova karilla, SOM, on kehittekoisiin neuroverkkoihin perustuva ohjaamattuman oppimisen menetelmä. SOM mahdollistaa moniulotteisen tiedon esittämisen ihmisen havainnollisemmassa, yleensä kaksiulotteisessa, muodossa.
- SOM pyrkii esittämään datan silen, eillä näytteiden väliset eläisyysdet uudessa kaksiulotteisessa koordinaatistossa vastaavat mahdollisimman hyvin todellisia näytteiden välistä eläisyksilä niiden alkuperäisessä koordinaatistossa. SOM ei erikseen pyri etsimään ja esittämään datasta sen sisältäviä ryhmittymiä, vaan esittää arvion datan todennäköisyydestä mahdollisimman uskottavasti säilyttää sen paikallisen rakenteen. Tämä tarkoittaa sitä, että jos kaksiulot-

teisella kartalla on nähtävissä tiheitä näytteiden muodostamia ryhmittymälä, niin myös todellisuudessa nämä näytteet sijaitsevat pilireavaruudessa twisi-aan läheillä. [13]

- 5 Jotta SOM:ia voitaisiin käyttää ryhmittelemään tiettytyyppistä dataa, läytyy se ensin opettaa. SOM opetetaan iteratiivisella ohjaamattomalla menetelmällä [13]. SOM:n opetuksen jälkeen jokaiselle kartan solmulle on asetettuna jokin piste moniulotteisessa avaruudessa, jota solmu vastaa. Algoritmi on säättänyt kartan opetusnäytteiden avulla. Moniulotteliset vektorit muodostavat 10 epälineaariset projektiot kaksiulotteiseen koordinaatistoon mahdollistaen ryhmittymien selkeän visualisoinnin [13].

SOM:n käyttäminen luokittelijana perustuu samankaltaisten näytteiden ryhmittymiseen lähekkäin toislaan, jolloin ne voidaan rajata omiksi luokikseen 15 kartalta. Kaukana toisistaan olevien solmujen näytteet ovat keskenään erilaisia, jolloin ne voidaan erottaa kuuluvan eri luokkiin. Kuvassa 4 on esitetty hyvän ja huonon paperin ryhmittyminen kartan vastakkaisiin nurkkiin. Kuvassa 6 on esitetty SOM:n käyttöä luokittelijana. Kuvan näytteet 61, 62 luokkiliivat luokkiin 63, 64. Karkeana esimerkkinä on käytetty hyvän paperin 61 luokittumista luokka-alueelle 63. ja Huonon paperin luokittumista alueelle 64. On huomattava että sekä hyvän, että huonon paperin alueita voi olla useita piirustutuneena eri osille esimerkiksi kaksiulotteista avaruulla. Kuitenkin niin, että esimerkiksi alueelle 64 luokittuva paperi on kaikki samalla tavalla huonoa. On ymmärrettävä, että tieto paperin valmistajalle on erittäin hyödyllistä 25 tietää, missä olisissa syntyy mainitunlaista paperia, jolla voidaan välittää huonaa laatuia tuottavia ulosuhleita luolannossa. Tämä on mahdollista seurauksilla luolannon parametreja ja luokittelua jatkuvasti paperin laatu, jolloin opitetaan prosessin turriminnaa uulla. ON myös mahdollista syöttää prosessin parametrit ja paperin luokittelun tulokset toiseen SOM-luokittelijaan, 30 jolloin saadaan aikaan virheistä oppiva järjestelmä, jota voidaan käyttää prosessin valvonnan apuna. Tällöin saadaan lopputulokseksi luokittelut joka ku-

vaa tuotannon olosuhteita suhteessa paperin laatuun. Järjeslelmä siis oppii esimerkiksi satojen muuttujien vaikuttusta paperin laatuun.

- Edellä on selostettu keksinnön mukaista luokittelua käytäen SOM-luokittelua,
- 5 mutta mikä tahansa valvomaton klusterointimenetelmä sopii käytettäväksi keksinnön mukaisesti luokitteluihin, esimerkiksi LLE, ISOMAP, GTM tekniikat, jotka eivät ole varsinaisia neuroverkkoteknikoita.

- Menetelmä sopii käytettäväksi paperin laaduntarkasluksessa paperin tuotannon aikana, esimerkiksi kaavikuvan 7 mukaisesti. Nopealla kameralla otetaan kuvia liikkuvasta paperirivalnasta 74 paperikoneen 75 yhteydessä. Kuvan kaaviossa on esitetty taustavalo 73, tarpeesta riippuen voidaan käyttää myös esimerkiksi vinoa etuvaloa. Kuville suoritetaan nopea analyysi. Tämän jälkeen voidaan tehdä päätelmiä tuotannossa olevan paperin laadullisista ominaisuuksista ja mahdollisesti säätää prosessin kulkua. Nyt esiteltävää menetelmää käytettäisiin kuvassa olevan tietokoneen 71 yhteydessä. Nopea kuvaanalyysi sekä havainnollinen käyttöliittymä suurelle mittausdatalle tarjoavat siunnartomasti IISÄ-Informaatiota valmislevylavasta paperista itse paperin valmistajalle.
- 10 20 Kuva-analyysissä otetulista kuvista irrotetaan piirteilä edellä mainituilla teknillillä sekä suoritetaan luokitus eri laaluluokkiin. Käyttöliittymän avulla voi seurata paperin laadun kehittymistä tuularinon edetessä.
- 15 25 Menetelmällä voidaan analysoida paperia miltei koko sen tuotantokaaren ajan. Taustavalon tehoa täytyy kuitenkin kasvattaa jos kuvia otetaan jo päälystetyistä paperista. Lisäksi tekstuuriplirteiden suontuskyky saattaa kärsiä päälystettyillä papereilla.

Tarkka tieto paperin laadusta sen tuotannon aikana helpollaan paperin valmistajan tekemää tutkimuksia. Auromaatiovalmistaja voi yhdistää järjestelmän osaksi koko prosessia, ja sen säätiöä.

- 5 Keksinnölle on tunnusomaista se, mitä on esitetty itsenäisissä patenttivaatimuksissa ja epäitsenäiser vaatimukset kuvaavat sen edullisia suoritusmuotoja.

L 2  
11Patenttivaatimukset

1. Kohenäköön perustuva paperin piirteiden karakterisointimenetelmä, tunnettu siitä, että lukuisten paperinäytteiden kuvista irrotetaan paperin ominaisuuksia kuvaavia moniluotettisia piirteitä; mainitut piirteet annetaan syöteenä ohjaamattomasti toimivaan oppivaan luokittelijaan, joka tuottaa kuvausmenetelmästä kunkin kuvan osan datasta pienempiulotteiseen avaruuteen siten, että ominaisuuksiltaan lähekkäiset paperilaadut tuollavat mainittuun pienempiulotteiseen avaruuteen lähekkäiset kuvausketjut ja pienempiulotteiseen avaruuteen kuvautuvia luokittelutuloksia käytetään luokittelun apuna.
2. Vaatimuksen 1 mukainen paperin karakterisointimenetelmä, tunnettu siitä, että mainittu ohjaamattomasti toimiva oppiva järjestelmä on valvomaan klusterointimenetelmä tai sen simulaatio, esimerkiksi SOM (Self Organizing Map).
3. Vaatimuksen 1 tai 2 mukainen paperin karakterisointimenetelmä, tunnettu siitä, että paperinäytteitä kuvaava piirre on LBP (Local Binary Pattern) tai siitä johdettu bittikuvioilippe.
4. Jokin edellä olevan vaatimuksen mukainen paperin piirteiden karakterisointimenetelmä, tunnettu siitä, että menetelmän mukaan lisäksi kuvataan ja luokitellaan paperia sen valmistuksen eri vaiheissa.
5. Vaatimuksen 4 mukainen paperin piirteiden karakterisointimenetelmä, tunnettu siitä, että eri valmistuksen vaiheissa kuvattuja näytteitä käsitellään saman paperin osalta edelleen ohjaamattomalla oppivalla luokittelijalla niin, että luokittelut kokee myös valmistusprosessin kulkua.

6. Vaatimuksen 5 mukainen järjestelmä, tunnettu siitä, että kuvainformaation lisäksi luokittelun syönteenä käytetään valittuja prosessiparametreja ja/tai mittaustuloksia.

- 5 7. Järjestelmä paperin luokittelemiseksi konenäköä käyttäen, tunnettu siitä, että järjestelmässä on kuvaamisvälineet, välineet paperin laatua kuvaavien piirteiden irrottamiseksi paperin kuvalta ja välineet ohjaamattomasti oppivaan luokittelun pääreavaruutta pienempiuolleiseen avaruuteen.

**Liite: Kirjallisuusviiteluettelo**

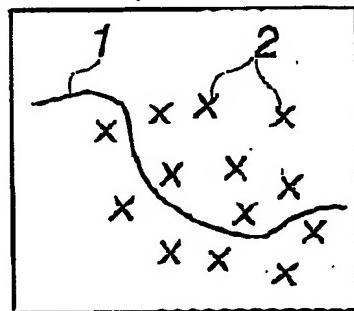
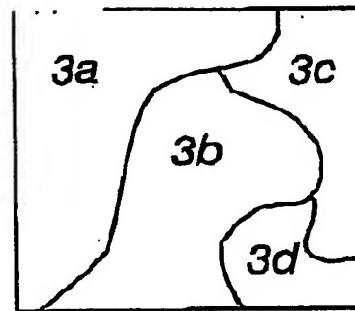
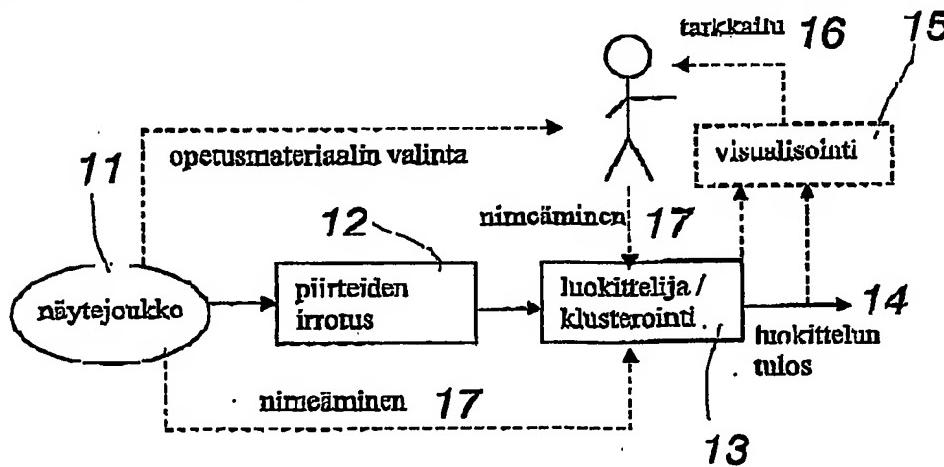
- [1] Cresson T.M., Tomimatsu H. & Luner P. (1990) Characterization of Paper Formation, Part 1: Sensing Paper Formation. *Tappi Journal*: Vol. 73, No. 7: s. 5 153-159.
- [2] Cresson T. & Luner P. (1990) Characterization of Paper Formation, Part 2: The Texture Analysis of Paper Formation. *Tappi Journal*: Vol. 73, No. 12: s. 175-184.
- 10 [2] Cresson T. & Luner P. (1991) Characterization of Paper Formation, Part 3: The Use of Texture Maps to Describe Paper Formation. *Tappi Journal*: Vol. 74, No. 2: s. 167-175.
- 15 [3] Sudhakara R.P., Stridhar R., Gopal A., Meenakshi K., Revathy R., Chitra K. & Palaniswami D. (2001) Optical Paper Formation Analyzer. CEERI Centre, India.
- 20 [4] Bernle J.P. & Douglas W.J.M. (1996) Local Grammage Distribution and Formation of Paper by Light Transmission Image Analysis. *Tappi Journal*: Vol. 79, No. 1: s. 193-202.
- 25 [5] Bouyndain M., Colombe J.F., Navarro R. & Pladelllorens J. (2001) Determination of Paper Formation by Fourier Analysis of Light Transmission Images. *Appita Journal*: Vol. 54, No. 2: s. 103-105, 115.
- [6] Kohonen T. (1997) Self-organizing Maps. Springer-Verlag, Berlin, Saksa, 426 s.

- [7] Roweis S.T. & Saul L.K. (2000) Nonlinear Dimensionality Reduction by Locally Linear Embedding. *Science Magazine*, Vol 290, 22 December 2000: s. 2323-2326.
- 5 [8] Roweis S.T. & Saul L.K. (2001) An Introduction to Locally Linear Embedding. URL: <http://www.cs.toronto.edu/~roweis/lle/papers/lleintroa4.pdf> (13.5.2002).
- [9] Svensén J.F.M. (1998) GTM: The Generative Topographic Mapping. Väitöskirja. Aston University, Englanti, 108 s.
- 10 [10] Tenenbaum J.B. (1998) Mapping a Manifold of Perceptual Observations. Advances in Neural Information Processing Systems, Vol. 10.
- 15 [11] Ojala T., Pietikäinen M. & Harwood D. (1996) A Comparative Study of Texture Measures With Classification Based on Feature Distributions. *Pattern Recognition*, Vol. 29, No. 1, s. 51-59.
- 20 [12] Ojala T., Pietikäinen M. & Mäenpää T. (2002) Multiresolution Gray-Scale and Rotation Invariant Texture Classification with Local Binary Patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 24, No. 7.
- [13] Kohonen T. (1997) Self-organizing Maps. Springer-Verlag, Berlin, Saksa, 426 s.

## (57) Tiivistelma

Menetelmä ja järjestelmä paperin karakterisointiin, jossa lukuisten paperinäytteiden kuvista irrotetaan paperin ominaisuuksia kuyaavia moniulotteisia piirteitä; määritetut piirteet annetaan syötteenä ohjaamattomasti tolivalaan oppivaan luokilleljaan, joka tuottaa kuvaukseen määritusta kunkin kuvan osan datasta pienempiulotteiseen avaruuteen siten, että ominaisuuksiltaan lähekkäiset paperilaadut tuottavat määrittämään pienempiulottelseen avaruuteen lähekkäiset kuvaukset ja pienempiulottelseen avaruuteen kuvauluvia luokiteltuloksia käytetään luokillelun apuna

2 4

*Fig.1 ja Fig.2. Piirreavaruuden pirstoutuminen ja klusterointuminen**Piirteiden pirstoutuminen**Fig.1**Moniulotteisen piirredalan klusterointuminen kaksiluotettiseen koordinaatistoon**Fig.2**Paperin karakterisointi käyttää ohjaamattomasti opetettavaa luokittelijaa**Fig.3*

L 4

2

## Alkuperäisen LBP-pisteen laskeminen

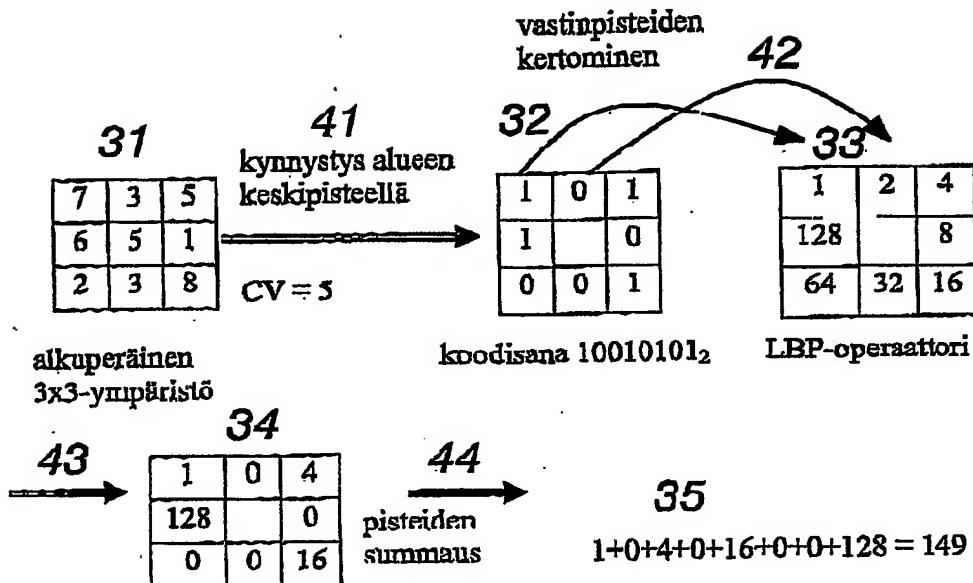


Fig.4

2 4

3

Pisteen ympyrän kehällä oleva naapurusto, joista LBP-piirre lasketaan

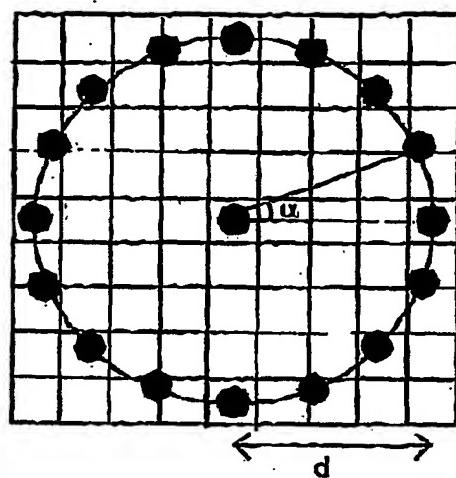
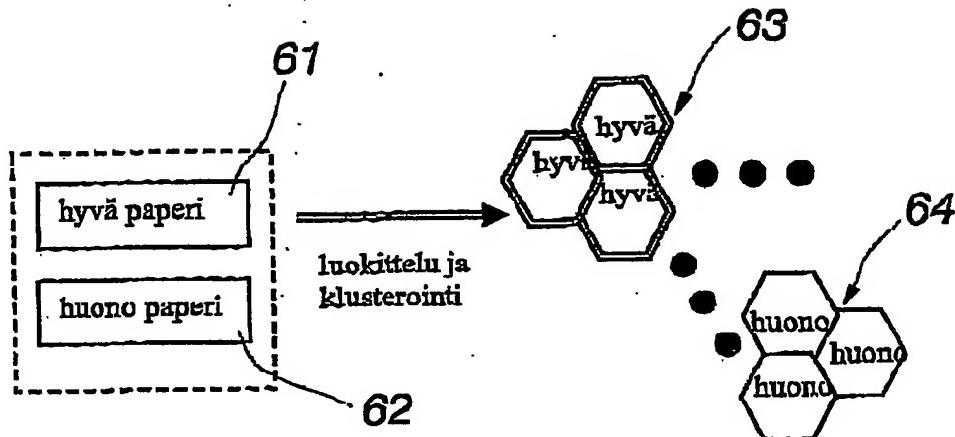


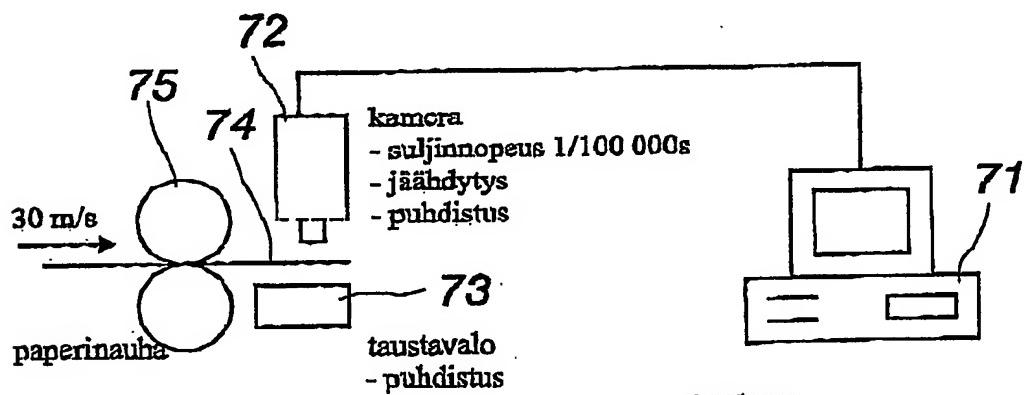
Fig.5

2 4

4

*Fig.6*

*Kaaviokuva konenäköjärjestelmästä tuotannon aikana suoritettavaan paperin karakterisointilin*



- tietokone
- tietokanta
  - kuvan kaappaus
  - kuva-analyysi
  - käyttöliittymä
  - prosessin ohjaus

*Fig.7*